

การประเมินประสิทธิภาพของโมเดลการเรียนรู้ของเครื่องแบบจำแนกประเภทการทำงานของระบบปรับอากาศในโรงเรือนระบบปิด

Performance Evaluation of Classification-Based Machine Learning Models for Air Conditioning Operation in a Closed-System Greenhouse

มาชิตา แดงสละ¹ ดุจดาว บุรณพณิษฐ์กิจ¹ อภิเดช บุรณวงศ์¹ เกียรติศักดิ์ เลี้ยงช่วย¹และ ณัฏฐา จินดาเพชร^{2*}

¹สาขาวิชาวิศวกรรมไฟฟ้าและชีวการแพทย์ คณะวิศวกรรมศาสตร์ มหาวิทยาลัยสงขลานครินทร์ 6610120007@email.psu.ac.th

dujdown.b@psu.ac.th bapidet@eng.psu.ac.th kiattisak.se@psu.ac.th

²สาขาวิชาวิศวกรรมไฟฟ้าและชีวการแพทย์ คณะวิศวกรรมศาสตร์ มหาวิทยาลัยสงขลานครินทร์ nattha.s@psu.ac.th*

บทคัดย่อ

งานวิจัยนี้นำเสนอการใช้โมเดลการเรียนรู้ของเครื่องสำหรับจำแนกการทำงานของระบบปรับอากาศในโรงเรือนระบบปิดภายใต้สภาพอากาศร้อนชื้น โดยจำแนกการทำงานออกเป็น 7 กรณีตามการเปิด-ปิดในแต่ละชั่วโมง ข้อมูลถูกเก็บจากระบบ IoT ในโรงเรือนต้นแบบ (3.0 × 2.4 × 3.0 เมตร) ทั้งอุณหภูมิ ความชื้น ภายใน-ภายนอก และพารามิเตอร์ทางไฟฟ้า จากนั้นพัฒนาแบบจำลองด้วย Quadratic SVM (QSVM), Cubic SVM (CSVM) และ Bagged Trees (BT) ผลการทดสอบพบว่า QSVM และ BT ให้ความแม่นยำสูงสุด 98.46% และ RMSE 0.2481 ขณะที่ CSVM มีความแม่นยำ 96.92% และ RMSE 0.3508 นอกจากนี้การประเมินเพิ่มเติมด้วย Precision, Recall, F1-score และ ROC-AUC ยืนยันว่า QSVM และ BT มีประสิทธิภาพเด่น เหมาะสำหรับการประยุกต์ในระบบเกษตรอัจฉริยะ

คำสำคัญ: โรงเรือนระบบปิด, การเรียนรู้ของเครื่องแบบการจำแนกประเภท, เกษตรอัจฉริยะ

Abstract

This study presents the application of machine learning models to classify air conditioning operations in a closed greenhouse under tropical climate conditions. The system was categorized into seven operation modes based on hourly on-off status. Data were collected from an IoT-based prototype greenhouse (3.0 × 2.4 × 3.0 m), including indoor-outdoor temperature, humidity, and electrical parameters. Three models—Quadratic SVM (QSVM), Cubic SVM (CSVM), and Bagged Trees (BT)—were developed and evaluated. Results showed that QSVM and BT achieved the highest accuracy of 98.46% with an RMSE of 0.2481, while CSVM achieved 96.92% accuracy with an RMSE of 0.3508. Additional evaluation using Precision, Recall, F1 - score, and ROC-AUC confirmed the superior performance of QSVM and BT, highlighting their potential for predictive analysis in smart agriculture systems.

Keywords: closed system greenhouse, machine learning, classification, smart agriculture

1. คำนำ

การทำเกษตรในโรงเรือนภายใต้สภาพภูมิอากาศแบบร้อนชื้นในภูมิภาคเขตร้อนนั้นถือเป็นบทบาทสำคัญ โดยเฉพาะการรักษาสภาวะแวดล้อมที่เหมาะสมสำหรับการเพาะปลูก ซึ่งหนึ่งในปัจจัยหลักคือการควบคุมอุณหภูมิภายในโรงเรือนที่จะส่งผลต่อคุณภาพของผักในช่วงฤดูร้อนที่มีอุณหภูมิภายนอกสูงมากเกินไป อย่างไรก็ตาม สำหรับประเทศที่อยู่ในภูมิภาคเขตร้อน เช่น ภาคใต้ของประเทศไทย โรงเรือนระบบปิดจะต้องเผชิญกับความท้าทายเพิ่มเติมจากสภาพอากาศที่มีอุณหภูมิสูงและความชื้นสัมพัทธ์แปรปรวนจากฤดูฝน ทำให้ระบบปรับอากาศต้องทำงานหนัก ส่งผลให้เกิดการใช้พลังงานที่สูงอย่างหลีกเลี่ยงไม่ได้ โดยเฉพาะในช่วงเดือนกันยายนและตุลาคมที่ข้อมูลจากกรมอุตุนิยมวิทยาแสดงให้เห็นว่าอุณหภูมิสูงสุดเฉลี่ยของทุกภาคอยู่ระหว่าง 32–34 [1] องศาเซลเซียส การเปิดระบบทำความเย็นในช่วงเวลาที่ไม่จำเป็นจึงกลายเป็นปัจจัยที่นำไปสู่การสูญเสียพลังงานอย่างไม่คุ้มค่า ดังนั้นการตัดสินใจเปิด-ปิดเครื่องปรับอากาศจึงไม่ควรพิจารณาเพียงตามเวลาแบบตายตัว แต่ควรอิงกับข้อมูลสภาพแวดล้อมจริง เช่น อุณหภูมิภายใน-ภายนอก ความชื้นสัมพัทธ์ และพฤติกรรมการใช้พลังงานของระบบ เพื่อให้การควบคุมมีประสิทธิภาพมากขึ้น งานวิจัยในช่วงหลังจึงเริ่มประยุกต์ใช้เทคนิคการเรียนรู้ของเครื่อง (Machine Learning) [2] เพื่อเข้ามาช่วยในเรื่องของการจัดการพลังงาน และควบคุมเงื่อนไขสิ่งแวดล้อมที่มีผลต่อผลผลิตและคุณภาพของพืช ซึ่งต้องมีการควบคุมสมดุลของปัจจัยสิ่งแวดล้อม รวมถึงอุณหภูมิ ความชื้น ความเข้มของแสง และระดับคาร์บอนไดออกไซด์เพื่อให้เกิดเจริญเติบโตของพืชเป็นไปอย่างดีที่สุด

ซึ่งแม้จะมีงานวิจัยที่พัฒนาอัลกอริทึมควบคุมสภาพแวดล้อมภายในโรงเรือน เช่น Adaptive Control[3], Proportional-Integral-Derivative (PID) [4],[6], Neural Network (NN) [5], Fuzzy Logic [6], Model และ Predictive Control (MPC) [7] แต่หลายแนวทางยังคงเผชิญข้อจำกัดในการประยุกต์ใช้จริง โดยเฉพาะในระบบต้นทุนต่ำที่มีข้อจำกัดด้านทรัพยากร และต้องรับมือกับสภาพแวดล้อมที่เปลี่ยนแปลงตลอดเวลา เช่น PID และ Fuzzy มักต้องอาศัยการจูนพารามิเตอร์หรือออกแบบกฎที่แม่นยำ ขณะที่ MPC และ NN ต้องการระบบประมวลผลที่มีประสิทธิภาพสูงและมีความซับซ้อนในการออกแบบแบบจำลอง ในทางกลับกัน แนวทางแบบ

ขับเคลื่อนด้วยข้อมูล (data-driven) โดยเฉพาะการจำแนกสถานการณ์ควบคุมด้วยเทคนิคการเรียนรู้ของเครื่อง (Machine Learning) เช่น โมเดลการจำแนกประเภท (Classification Models) โดยมุ่งเป้าไปที่การควบคุมแบบเปิด-ปิดของระบบปรับอากาศเพื่อรักษาอุณหภูมิให้เหมาะสม คือ 23-27°C ในแต่ละช่วงเวลา ซึ่งจะช่วยให้ประหยัดพลังงานทางอ้อม แทนที่จะเป็นการปรับความถี่ของแรงดันไฟฟ้ากระแสสลับ (AC) ที่ป้อนเข้าสู่คอมเพรสเซอร์ของเครื่องปรับอากาศโดยตรง เนื่องจากการควบคุมอุณหภูมิอย่างละเอียดโดยการปรับความถี่นั้นจำเป็นต้องมีโมเดลทางคณิตศาสตร์ของระบบเครื่องปรับอากาศ ดังนั้นเทคนิคการตัดสินใจการควบคุมแบบจำแนกประเภทที่งานวิจัยนี้นำเสนอจึงมีความยืดหยุ่นและง่ายต่อการนำไปประยุกต์ใช้กับไมโครคอนโทรลเลอร์ที่มีต้นทุนต่ำ เนื่องจากไม่จำเป็นต้องอาศัยแบบจำลองทางคณิตศาสตร์อย่างละเอียดเทียบกับระบบอื่นๆ

งานวิจัยนี้จึงมีวัตถุประสงค์เพื่อพัฒนาและเปรียบเทียบโมเดลการเรียนรู้ของเครื่องแบบจำแนกประเภทที่เหมาะสมที่สุดในการจำแนกสถานการณ์การเปิด-ปิดระบบปรับอากาศ โดยใช้ข้อมูลจากโรงเรือนจริงในพื้นที่จังหวัดสงขลา ซึ่งรวบรวมพารามิเตอร์ทั้งทางสิ่งแวดล้อม (เช่น อุณหภูมิภายนอก-ภายใน ความชื้น) และพลังงานไฟฟ้า (เช่น กระแสแรงดัน และพลังงานไฟฟ้าที่ใช้) แล้วนำเข้าสู่อัลกอริทึมการฝึกสอนโมเดลด้วยซอฟต์แวร์ MATLAB เพื่อเปรียบเทียบประสิทธิภาพของโมเดลประเภทต่างๆ โดยใช้เกณฑ์การประเมิน เช่น ความแม่นยำและค่ารากที่สองของความผิดพลาดเฉลี่ย (RMSE) ซึ่งสามารถนำไปประยุกต์ใช้ในระบบควบคุมการเปิด-ปิดเครื่องปรับอากาศอัตโนมัติในอนาคต เช่น การเชื่อมต่อกับระบบควบคุมอัตโนมัติ หรือการประยุกต์กับระบบพลังงานหมุนเวียน ซึ่งจะเพิ่มประโยชน์ต่อเกษตรกรในการลดต้นทุนด้านพลังงาน และเพิ่มประสิทธิภาพในการควบคุมสภาพแวดล้อมในโรงเรือนอย่างยั่งยืน

2. ทฤษฎีที่เกี่ยวข้อง

2.1 การเรียนรู้ของเครื่อง (Machine Learning)

การเรียนรู้ของเครื่องคือส่วนหนึ่งของปัญญาประดิษฐ์ (Artificial Intelligence) ที่เน้นการพัฒนาแบบที่สามารถเรียนรู้จากข้อมูลและปรับปรุงสมรรถนะของตนเองโดยไม่ต้องเขียนโปรแกรมที่ชัดเจนในการทำงานแต่ละขั้นตอน โดยอาศัยอัลกอริทึมต่างๆ เพื่อวิเคราะห์ข้อมูลประมวลผล และสร้างแบบจำลองเชิงคาดการณ์ (Predictive Model)

2.2 Quadratic SVM (QSVM)

Support Vector Machine (SVM) เป็นหนึ่งในเทคนิคการจำแนกประเภทที่มีประสิทธิภาพสูง โดยอาศัยแนวคิดของการหาขอบเขต (Decision Boundary) ที่เหมาะสมที่สุดในการจำแนกข้อมูลออกเป็นแต่ละคลาส โดยจะพยายามสร้างเส้นแบ่ง (Hyperplane) ที่มีระยะห่าง (Margin) สูงสุดจากข้อมูลของแต่ละกลุ่ม จุดข้อมูลที่อยู่ใกล้ขอบเขตที่สุดเรียกว่า Support Vectors โดย QSVM คือรูปแบบหนึ่งของ SVM ที่ใช้

Polynomial Kernel ลำดับที่ 2 ซึ่งสามารถนิยามได้ด้วยสมการพื้นฐานของ Polynomial Kernel [8]

$$k(x, x') = (x \cdot x' + c)^d \quad (1)$$

โดยที่ x, x' คือเวกเตอร์ของข้อมูล, d คือลำดับของพหุนาม ซึ่งในกรณีของ QSVM มีค่า $d = 2$ และ c คือค่าคงที่ (bias term)

2.3 Cubic SVM (CSVM)

CSVM เป็นอีกหนึ่งประเภทของ SVM ที่ใช้ Polynomial Kernel Function ลำดับที่สาม (Degree 3) เพื่อให้โมเดลสามารถเรียนรู้ข้อมูลที่มีความซับซ้อนยิ่งขึ้น และมีการแปรผันของพีเจอรที่มากกว่าระดับ QSVM โดย Kernel Function ของ CSVM นั้นจะนิยามได้ด้วยสมการที่ 1 โดยที่ $d = 3$ ซึ่งให้ความยืดหยุ่นที่มากขึ้นในการจับรูปแบบของข้อมูลที่ซับซ้อนและไม่เป็นเส้นตรง เหมาะอย่างยิ่งกับสถานการณ์ที่ความสัมพันธ์ระหว่างพีเจอรไม่สามารถแยกกันได้ด้วยเส้นตรง (Linearly Inseparable)

2.4 Ensemble Bagged Trees (BT)

Bagged Trees หรือ Bootstrap Aggregating (Bagging) เป็นเทคนิคการเรียนรู้แบบ Ensemble Learning ที่รวมผลลัพธ์จากหลายโมเดลย่อย (Weak Learners) เข้าด้วยกันเพื่อสร้างโมเดลที่มีความแม่นยำและความเสถียรมากขึ้น ในกรณีนี้ โมเดลย่อยคือ Decision Trees ซึ่งแต่ละต้นจะถูกฝึกด้วยชุดข้อมูลที่แตกต่างกันโดยใช้เทคนิค Bootstrap Sampling คือการสุ่มเลือกข้อมูลซ้ำจากชุดข้อมูลต้นฉบับ ซึ่งผลลัพธ์จากแต่ละต้นไม่ถูกรวมด้วยวิธีการ Majority Voting สำหรับการจำแนกประเภท โดยไม่จำเป็นต้องใช้แบบจำลองคณิตศาสตร์ที่ซับซ้อน

2.5 การเลือกคุณลักษณะ (Feature Selection) โดยใช้

หลักการ mRMR (Minimum Redundancy Maximum Relevance)

การเลือกคุณลักษณะ (Feature Selection) เป็นขั้นตอนสำคัญในกระบวนการพัฒนาโมเดล Machine Learning โดยเฉพาะอย่างยิ่งในระบบที่มีจำนวนพีเจอรมาก ซึ่งอาจส่งผลให้เกิดความซ้ำซ้อนของข้อมูลและลดประสิทธิภาพของโมเดล mRMR (Minimum Redundancy Maximum Relevance) เป็นหนึ่งในเทคนิคการเลือกพีเจอรที่มีประสิทธิภาพ ซึ่งถูกออกแบบมาเพื่อสร้างสมดุลระหว่างสองวัตถุประสงค์หลักที่ขัดแย้งกัน ได้แก่ Relevance (ความเกี่ยวข้อง) คือความสามารถของพีเจอรในการอธิบายหรือมีความสัมพันธ์กับตัวแปรเป้าหมาย (target class) และ Redundancy (ความซ้ำซ้อน) ความสัมพันธ์ระหว่างพีเจอรที่ถูกเลือกด้วยตัวเอง ซึ่งควรน้อยที่สุดเพื่อไม่ให้เกิดการทับซ้อนของข้อมูล โดยหลักการของ mRMR จะทำการเลือกพีเจอรที่มีความเกี่ยวข้องกับตัวแปรเป้าหมายสูงสุด และในขณะเดียวกันก็มีความซ้ำซ้อนกับพีเจอรที่ถูกเลือกไว้น้อยที่สุด มีสมการดังนี้ [9]

$$\text{Rel}(S) = \frac{1}{|S|} \sum_{x_i \in S} I(x_i; c) \quad (2)$$

$$\text{Rel}(S) = \frac{1}{|S|^2} \sum_{x_i, x_j \in S} I(x_i; x_j) \quad (3)$$

โดยที่ $S \subset X$ คือเซตของฟีเจอร์ที่ถูกเลือกจากฟีเจอร์ทั้งหมด X , $I(x_i; c)$ คือความเกี่ยวข้องระหว่างฟีเจอร์ x_i กับคลาสเป้าหมาย c และ $I(x_i; x_j)$ คือความซ้ำซ้อนระหว่างฟีเจอร์ x_i กับ x_j

$$\text{mRMR} = \max_{x_i \in X - S} \left[I(x_i; c) - \frac{1}{|S|} \sum_{x_j \in S} I(x_i; x_j) \right] \quad (4)$$

โดยที่ $X - S$ คือเซตของฟีเจอร์ที่ยังไม่ได้ถูกเลือก, $I(x_i; c)$ คือความเกี่ยวข้องของฟีเจอร์ใหม่กับคลาส และ $I(x_i; x_j)$ คือความซ้ำซ้อนระหว่างฟีเจอร์ใหม่กับฟีเจอร์ที่เลือกแล้ว

3. การดำเนินงานวิจัย

3.1 ข้อกำหนดของระบบ (System Specification)

ระบบทดลองถูกติดตั้งในโรงเรือนขนาดเล็ก ซึ่งถูกออกแบบเป็นระบบปิด (Closed System) ซึ่งมีขนาด 3.0 เมตร × 2.4 เมตร × 3.0 เมตร (ยาว × กว้าง × สูง) โดยภายในโรงเรือนมีการติดตั้งระบบปรับอากาศ (1,047W) สำหรับควบคุมอุณหภูมิภายใน ซึ่งเป็นปัจจัยสำคัญในภูมิอากาศแบบร้อน และมีการพัฒนาระบบ IoT สำหรับการตรวจวัดและเก็บข้อมูลสภาพแวดล้อม โดยมีการติดตั้งเซนเซอร์วัดอุณหภูมิและความชื้นในตำแหน่งสำคัญหลายจุดทั้งภายในและภายนอกโรงเรือน (ดังแสดงในรูปที่ 1(ก) และรูปที่ 1(ข)) รวมถึงการวัดค่ากำลังไฟฟ้า แรงดัน และกระแสไฟฟ้า โดยใช้เซนเซอร์ PZEM-004T ซึ่งเซนเซอร์เหล่านี้จะวัดข้อมูลแบบเรียลไทม์อย่างต่อเนื่องทุกๆ 5 นาที ซึ่งข้อมูลจากเซนเซอร์จะถูกประมวลผลผ่านไมโครคอนโทรลเลอร์ ESP8266 และส่งขึ้นสู่แพลตฟอร์ม Google Sheet เพื่อจัดเก็บและแสดงผล โดยระบบควบคุมจะใช้โมเดลการเรียนรู้ของเครื่องแบบจำแนกประเภทที่ได้รับการฝึกฝนใน MATLAB เพื่อกำหนดช่วงเวลาที่เหมาะสมในการเปิดใช้งานระบบทำความเย็นที่เพิ่มประสิทธิภาพการใช้พลังงานพร้อมทั้งยังคงรักษาสภาพแวดล้อมที่เหมาะสมสำหรับการเจริญเติบโตของผัก



(ก)

(ข)


รูปที่ 1 (ก), (ข) การติดตั้งเซนเซอร์วัดอุณหภูมิและความชื้น SHT45 ภายในและภายนอก ตามลำดับ

3.2 การเตรียมข้อมูลดิบ (Raw Data)

ในงานนี้มีการใช้วิธีการแบบขับเคลื่อนด้วยข้อมูล (Data-driven method) โดยการเปิดระบบทำความเย็นตลอดเวลา (Case 1) การเปิดปิดบางช่วงเวลา (Case 2-6) ไปจนถึงการปิดการทำงานทั้งหมด (Case 7) ดังแสดงในตารางที่ 1 โดยแต่ละกรณีจะกำหนดอัตราส่วนการเปิด-ปิด ของระบบทำความเย็นเฉพาะระหว่างการทดลอง ซึ่งได้ดำเนินการเก็บข้อมูลจากโรงเรือนตั้งแต่วันที่ 16 ต.ค.2567 ถึง 31 พ.ค. 2568 เป็นเวลา 6 เดือน 16 วัน หรือรวมกัน 228 วัน โดยข้อมูลถูกแบ่งออกเป็นสามช่วงเวลา ได้แก่ ช่วงเช้า (09:00–12:00), ช่วงบ่าย (13:00–16:00) และช่วงเย็น (18:00–00:00) ซึ่งจะทำให้การคัดเลือกข้อมูลเข้าสู่การฝึกสอนเฉพาะช่วงที่กรณีนั้นๆ สามารถควบคุมอุณหภูมิภายในโรงเรือนให้อยู่ภายในช่วง 23–27°C พร้อมกับเปรียบเทียบการใช้พลังงาน (E: kWh) ของระบบปรับอากาศให้เป็นไปอย่างเหมาะสมและไม่สิ้นเปลือง ซึ่งหากกรณีใดในวันนั้นๆ ไม่สามารถทำอุณหภูมิให้อยู่ในช่วงที่กำหนด และไม่ประหยัดพลังงานจะทำให้การตัดข้อมูลช่วงนั้นออกทันที เพื่อไม่ให้โมเดลเรียนรู้การจำแนกที่ผิดพลาด

3.3 การพัฒนาโมเดล (Model Development)

ในหัวข้อนี้กล่าวถึงโมเดลการเรียนรู้ของเครื่อง และระเบียบวิธีที่ใช้ในการจำแนกกลยุทธ์การควบคุมเครื่องปรับอากาศที่เหมาะสมในสภาพแวดล้อมของโรงเรือน โดยได้พัฒนาและฝึกฝนโมเดลการจำแนกประเภทแบบ Supervised Learning ทั้งหมดสามโมเดลโดยใช้เครื่องมือ Classification Learner App ของ MATLAB 2023a โดยโมเดลทั้งหมดถูกฝึกโดยใช้ชุดคุณลักษณะที่ได้จากการคัดเลือก โดยข้อมูลถูกแบ่งออกเป็นชุดฝึก (80%) เป็นจำนวน 265 ชุด และชุดทดสอบ (20%)



รูปที่ 2 ขั้นตอนการพัฒนาโมเดล

เป็นจำนวน 62 ชุด ซึ่งชุดฝึกถูกใช้ในการฝึกโมเดลและประเมินแบบ Cross-validation แบบ 5-fold ดังแสดงในรูปที่ 2

ตารางที่ 1 กรณีการควบคุมเครื่องปรับอากาศและอัตราส่วนเวลาเปิด-ปิด

กรณีการควบคุมเครื่องปรับอากาศ	เปิด ปิด (นาที)
Case 1	เปิดตลอด
Case 2	50 10
Case 3	40 20
Case 4	30 30
Case 5	20 40
Case 6	10 50
Case 7	ปิดตลอด

3.4 กระบวนการตัดคุณลักษณะออกจากชุดข้อมูล

(Feature Elimination)


หลังจากทำการเลือกโมเดลแล้ว จึงได้ดำเนินการใช้กระบวนการตัดลดฟีเจอร์หรือคุณลักษณะด้วยตนเอง (Feature Elimination) และได้มีการใช้เทคนิค mRMR เพื่อจัดลำดับความสำคัญของตัวแปรอินพุตทั้งหมดที่เกี่ยวข้องกับการควบคุมอุณหภูมิภายในโรงเรือน โดยใช้เครื่องมือจาก MATLAB Classification Learner Toolbox ซึ่งมีฟังก์ชันรองรับการประเมินคุณลักษณะโดยใช้การวัดจากระดับของการพึ่งพากันทางสถิติ (Mutual Information) เพื่อคัดเลือกฟีเจอร์ที่มีความสัมพันธ์สูงกับตัวแปร โดยรูปที่ 2 ซึ่งแสดงวิธีที่ทำการลบคุณลักษณะออกทีละตัว โดยเริ่มจากตัวที่มีความสำคัญน้อยที่สุดซึ่งพิจารณาจากค่า mRMR จากนั้นจึงฝึกโมเดลซ้ำและวิเคราะห์ผลการเปลี่ยนแปลงของความแม่นยำในการ Cross-Validation ในแต่ละครั้งจากคุณลักษณะทั้งหมด 15 รายการที่ระบุไว้ในรูปที่ 3 ประกอบด้วยตัวแปรด้านเวลา สภาพแวดล้อม พารามิเตอร์ทางไฟฟ้า และค่าควบคุมอุณหภูมิ โดยแสดงความหมายและสมการไว้ดังตารางที่ 2

4. อภิปรายผลการทดลอง


หัวข้อนี้นำเสนอผลการวิเคราะห์ข้อมูลและผลลัพธ์ที่ได้จากกระบวนการพัฒนาโมเดลการทำงานของระบบปรับอากาศภายในโรงเรือนเพาะปลูก โดยมีเป้าหมายเพื่อปรับปรุงประสิทธิภาพความแม่นยำของโมเดลในการจำแนกสถานะการณ์ของเครื่องปรับอากาศว่าควรเลือกการเปิด-ปิดแบบใด ในการรักษาอุณหภูมิและพลังงานที่ไม่สิ้นเปลือง โดยใช้เทคนิคใช้เทคนิคการเลือกคุณลักษณะจากวิธี mRMR เป็นหลักในการประเมินเพื่อระบุชุดข้อมูลที่มีความสำคัญและไม่ซ้ำซ้อน ซึ่งจากรูปที่ 3 แสดงลำดับความสำคัญของฟีเจอร์ตามค่า mRMR ที่ได้จาก MATLAB Classification Learner App โดยฟีเจอร์ที่ได้คะแนน mRMR สูงสุด ได้แก่ IH (0.7792), deltaTinside (0.6637), time_period (0.5253) และ OH (0.4921) ต่อมาหัวข้อนี้ยังได้นำเสนอผลการพัฒนาและทดสอบโมเดลจำแนกประเภทการควบคุมระบบปรับอากาศด้วยอัลกอริทึมต่างๆ ได้แก่ QSVM, CSVM และ BT พร้อมทั้งเปรียบเทียบประสิทธิภาพโดยใช้ตัวชี้วัดต่างๆ เช่น Accuracy

ตารางที่ 2 คุณลักษณะทั้งหมดและความหมายหรือสมการ


Feature	Equation/Meaning
Hours	เวลาในรูปแบบ 24 ชั่วโมงซึ่งแปลงจากรูปแบบ hh:mm:ss เพื่อแยกเฉพาะชั่วโมง
time_period	เช้า = 1, บ่าย = 2, เย็นถึงค่ำ = 3
LowerTemp	ค่าต่ำสุดของช่วงอุณหภูมิที่เหมาะสม -2°C จากค่าที่ตั้ง คือ 23°C
TempSet	ค่าตั้งเป้าอุณหภูมิ ในงานนี้ใช้ 25°C
UpperTemp	ค่าสูงสุดของช่วงอุณหภูมิที่เหมาะสม +2°C จากค่าที่ตั้ง คือ 27°C
Otemp, OH	อุณหภูมิภายนอก, ความชื้นสัมพัทธ์ภายนอก
ITemp, IH	อุณหภูมิภายใน, ความชื้นสัมพัทธ์ภายใน
Voltage	แรงดันไฟฟ้า (V)
Current	กระแสไฟฟ้า (A)
Power	กำลังไฟฟ้า (W)
deltaToutside	$\Delta T_{outside} = T_{outside}(t) - T_{outside}(t-1)$
deltaTinside	$\Delta T_{inside} = T_{inside}(t) - T_{inside}(t-1)$
deltaTinout	$\Delta T_{out-in} = T_{outside}(t) - T_{inside}(t)$



รูปที่ 3 แผนภูมิแท่งของคะแนนความสำคัญของคุณลักษณะที่จัดเรียงตามอัลกอริทึม mRMR



รูปที่ 4 การเปรียบเทียบค่าความแม่นยำในการ training



รูปที่ 5 การเปรียบเทียบค่าความแม่นยำในการ testing

4.1 การเลือกโมเดลที่มีประสิทธิภาพดีที่สุด

งานวิจัยนี้ได้ดำเนินการคัดกรองตัวแปรอินพุตหรือฟีเจอร์เพิ่มเติมโดยจะทำการลบตัวแปรที่ละตัวโดยเริ่มจากตัวที่มีความสำคัญน้อยที่สุด และทำการฝึกซ้ำและประเมินผลโมเดลใหม่ในทุกขั้นตอน โดยใช้ชุดข้อมูลสำหรับการฝึก (training) และการทดสอบ (testing) เพื่อประเมินผลความแม่นยำแต่ละตัวแปรต่อความแม่นยำของโมเดลเมื่อใช้จำนวนฟีเจอร์ที่แตกต่างกัน โดยใช้โมเดล QSVM, CSVM และ BT

จากผลการประเมินที่แสดงในรูปที่ 4 และรูปที่ 5 พบว่าเมื่อนำผลของการฝึก (training) และทดสอบ (testing) มาเปรียบเทียบกับ พบว่า QSVM ที่ใช้ตัวแปร 11 ตัว ให้ค่าความแม่นยำสูงสุดที่ 98.46% ในชุดทดสอบ และ 97.74% ในชุดฝึก แสดงถึงความสามารถในการจำแนกที่ดีและไม่มีการ Overfitting ขณะที่ CSVM แม้จะให้ค่าความแม่นยำที่ 96.92% แต่ก็ต่ำกว่าเล็กน้อย ขณะที่ BT ซึ่งใช้เพียง 5 ตัวแปร ให้ค่าความแม่นยำชุดทดสอบเท่ากับ QSVM ที่ 98.46% แต่ความแม่นยำชุดฝึกอยู่ที่ 96.23% แสดงว่า BT เหมาะกับกรณีที่ต้องการประสิทธิภาพในการคำนวณและจำนวนตัวแปรน้อย เช่น ในระบบที่มีทรัพยากรจำกัด

ดังนั้น QSVM ที่ใช้ตัวแปร 11 ตัวจึงเป็นทางเลือกหลักสำหรับระบบควบคุมโรงเรือนที่ต้องการสมดุลระหว่างความแม่นยำและความซับซ้อน ขณะที่ BT เป็นตัวเลือกสำรองที่เหมาะสมสำหรับงานภาคสนามหรือระบบที่เน้นความรวดเร็วและง่ายในการนำไปใช้จริง และเพื่อทำการคัดเลือกโมเดลข้างต้นเหมาะสมกับความเป็นจริง ในหัวข้อถัดไป (4.2) จะเจาะลึกรูปแบบความผิดพลาดในการจำแนก ของแต่ละโมเดลจากเมทริกซ์ความสับสนและตัวชี้วัดรายคลาส (P/R/F1) โดยเฉพาะกรณีที่ คลาส 3 และคลาส 5 มีแนวโน้มสลับกัน ซึ่งมีนัยต่อ การตั้งรอบเวลาเปิด-ปิด และประสิทธิภาพการใช้พลังงานภายในโรงเรือนในเรื่องของการประหยัดพลังงาน

4.2 การวิเคราะห์ Confusion Matrix ร่วมกับตัวชี้วัด

เสริม (P/R/F1, ROC-AUC) และผลต่อการควบคุม

รูปที่ 6, รูปที่ 7 และ รูปที่ 8 คือผลความผิดพลาดในการจำแนกจากการฝึกฝนโมเดลใน Classification Learner App และได้มีการระบุเป็น Class ซึ่งเป็นความหมายเดียวกับ Case หรือกรณีในงานนี้ใช้ โดยงานนี้จะอธิบายโดยใช้คำว่า Class เพื่อให้สอดคล้องกับผลที่เกิดขึ้น

รูปที่ 6 พบว่าโมเดล QSVM สามารถจำแนก Class 1, 5 และ 7 ได้ถูกต้อง 100% ส่วน Class 3 มี TPR เท่ากับ 80.6% และถูกจำแนกผิดเป็น Class 5 จำนวน 19.4% ซึ่งสะท้อนว่าโมเดลสามารถแยกแยะควบคุมแบบเปิดตลอด (Always On) หรือปิดตลอด (Always Off) ได้ดีเยี่ยม แต่ยังมีคลาดเคลื่อนเล็กน้อยระหว่าง Class 3 (เปิดแอร์ 40 นาฬิกา/ปิด 20 นาฬิกา) กับ Class 5 (เปิดแอร์ 20 นาฬิกา/ปิด 40 นาฬิกา)

รูปที่ 7 แสดงผลของ CSVM ซึ่งมี TPR ของ Class 3 ต่ำกว่าที่ 77.4% และ FNR สูงขึ้นเป็น 22.6% แต่ยังคงไม่มีการจำแนกผิดในลักษณะที่รุนแรง เช่น การสลับจาก Always On ไป Always Off หรือในทางกลับกัน ซึ่งช่วยลดความเสี่ยงจากการควบคุมผิดพลาดที่ส่งผลกระทบต่ออุณหภูมิหรือพลังงานอย่างมีนัยสำคัญ

ในทางตรงกันข้าม จากรูปที่ 8 ของ BT พบว่าการจำแนก Class 3 และ Class 5 มีการสลับกันสองทิศทาง โดย Class 3 มี TPR เท่ากับ 80.6% ขณะที่ Class 5 มี TPR ที่ลดลงเป็น 86.2% และมีการจำแนกผิดเป็น Class 3 จำนวน 13.8% อย่างไรก็ตามเนื่องจากทั้งสองคลาสยังอยู่ในขอบเขตที่มีการเปิดระบบทำความเย็นอยู่ จึงไม่ส่งผลกระทบต่อความปลอดภัย แต่จะมีผลในเรื่องของรอบเวลาเปิด-ปิดที่อาจคลาดเคลื่อนเล็กน้อย

จากผลการวิเคราะห์เมทริกซ์ความสับสน พบว่ายังมีข้อผิดพลาดในการจำแนก Class 3 (เปิดแอร์ 40 นาฬิกา/ปิด 20 นาฬิกา) และ Class 5 (เปิดแอร์ 20 นาฬิกา/ปิด 40 นาฬิกา) ในทุกโมเดลที่ทดสอบ แม้ว่าข้อผิดพลาดดังกล่าวจะไม่ส่งผลกระทบต่อความปลอดภัยสภาพแวดล้อม เนื่องจากทั้งสองคลาสยังอยู่ในขอบเขตที่ระบบทำความเย็นทำงานอยู่ แต่การลดข้อผิดพลาดในกรณีที่มียุทธศาสตร์การเปิด-ปิดใกล้เคียงกัน จะช่วยให้การควบคุมมีความละเอียดและประหยัดพลังงานได้ดีขึ้น นอกจากนี้ การที่งานวิจัยจำเป็นต้องตัดข้อมูลบางส่วนที่ไม่สามารถรักษาอุณหภูมิให้อยู่ในช่วง 23–27°C หรือมีการใช้พลังงานเกินความเหมาะสม อาจทำให้โมเดลไม่สามารถเรียนรู้รูปแบบได้อย่างเพียงพอ โดยเฉพาะอย่างยิ่งเมื่อการใช้งานต้องครอบคลุมฤดูกาลที่หลากหลายเนื่องจากปริมาณของข้อมูลน้อยเกินไป ซึ่งหากข้อมูลมีปริมาณที่เพียงพอและครอบคลุมทุกฤดูกาล จะสามารถนำมาใช้ประโยชน์ได้ในอนาคตสำหรับฤดูกาลอื่นๆ ที่มีสภาพอากาศต่างกัน

ตารางที่ 3 ผลการประเมินแบบย่อยของโมเดลบนชุดทดสอบ (คลาส 1, 3, 5, 7): Macro-F1, Weighted-F1 และตัวชี้วัดสำคัญรายคลาส


MODEL	MACRO-F1	WEIGHTED-F1	CLASS 3 RECALL	CLASS 5 F1
QSVM	0.958	0.984	0.80	0.941
CSVM	0.910	0.967	0.60	0.889
BT	0.961	0.985	1.00	0.933

หมายเหตุ: CLASS 1 และ 7 ทุกโมเดลได้ P/R/F1 = 1.00; ข้อควรคือ CLASS 3 ที่ CSVM มี RECALL ต่ำ (0.60) ขณะที่ QSVM = 0.80 และ BT = 1.00.


ตารางที่ 3 สรุปสาระสำคัญจากเมทริกซ์ความสับสน โดยรายงานค่า Macro-F1/Weighted-F1 (ภาพรวม) และชี้ข้อควรที่คลาส 3 ด้วยค่า Recall ควบคู่กับ ประสิทธิภาพการจำแนกของคลาส 5 ด้วยค่า F1 สำหรับแต่ละโมเดล ผลลัพธ์สอดคล้องกับการวิเคราะห์ก่อนหน้านี้: QSVM และ BT ให้ผลโดยรวมดีกว่า (Macro-F1 = 0.958 และ 0.961) ขณะที่ CSVM มีปัญหาที่ คลาส 3 (Recall = 0.60) เมื่อเทียบกับ QSVM (0.80) และ BT (1.00) สำหรับ คลาส 5 นั้น QSVM และ BT รักษา F1 ได้สูง (0.941 และ 0.933) ส่วน คลาส 1 และ คลาส 7 ถูกจำแนกได้สมบูรณ์โดยทุกโมเดล (P/R/F1 = 1.00) จึงไม่แสดงซ้ำในตาราง ดังนั้นสำหรับการใช้งานในการควบคุมจริง โมเดลที่เหมาะสมคือ BT หากต้องการลดความผิดพลาดของคลาส 3 (ให้ความครอบคลุมสูงสุด) หรือ QSVM หากต้องการความสมดุลของเมตริกโดยรวม

5. สรุป


งานวิจัยนี้ได้ประเมินประสิทธิภาพโมเดลการเรียนรู้ของเครื่องแบบจำแนกประเภท สำหรับการทำนายการทำงานของระบบปรับอากาศใน



รูปที่ 6 เมทริกซ์ความสับสน QSVM



รูปที่ 7 เมทริกซ์ความสับสน CSVM



รูปที่ 8 เมทริกซ์ความสับสน BT

โรงเรือนระบบปิด ได้แก่ QSVM, CSVM และ BT เพื่อจำแนกกรณีการเปิด-ปิด ที่ดีที่สุดสำหรับระบบบทความในเรื่องของการประหยัดพลังงาน เพื่อใช้ในการเป็นคำตอบให้กับคอนโทรลเลอร์หรือระบบควบคุม จากผลการทดลองพบว่า QSVM และ BT ให้ค่าความแม่นยำสูงสุดที่ 98.46% และค่า RMSE ที่ต่ำ (0.2481)

แม้ว่าผลการทดลองจะแสดงให้เห็นถึงศักยภาพของโมเดล QSVM และ BT ที่สามารถให้ความแม่นยำสูงและมีความเหมาะสมต่อการนำไปใช้งานจริง แต่ข้อจำกัดที่สำคัญของงานวิจัยนี้คือปริมาณและความหลากหลายของข้อมูลที่ยังครอบคลุมเพียงบางช่วงฤดูกาลเท่านั้น ดังนั้นงานวิจัยในอนาคตควรขยายการเก็บข้อมูลให้ครอบคลุมทั้งปี เพื่อสะท้อนความผันแปรของสภาพอากาศในฤดูร้อนและฤดูฝน ซึ่งจะช่วยเพิ่มความแข็งแกร่งและความน่าเชื่อถือของโมเดลในการตัดสินใจภายใต้สภาวะที่แตกต่างกันตลอดทั้งปี อีกทั้ง การนำโมเดลที่พัฒนาแล้วไปติดตั้งและทดสอบในโรงเรือนจริงแบบเรียลไทม์ ถือเป็นขั้นตอนสำคัญในการยืนยันความเสถียรและความสามารถในการปรับตัวของระบบภายใต้สภาพการดำเนินงานจริงที่ไม่สามารถจำลองได้ทั้งหมดในห้องปฏิบัติการ ข้อมูลที่ได้จากการทดลองใช้งานจริงยังสามารถนำกลับมาใช้ปรับปรุงโมเดลให้มีประสิทธิภาพ

ยิ่งขึ้น และเป็นก้าวต่อไปในการพัฒนาเทคโนโลยีการจัดการพลังงานในโรงเรือนอย่างยั่งยืน

เอกสารอ้างอิง

- [1] T. M. Department. "Thailand weather." <https://www.tmd.go.th/> (accessed May 25, 2023).
- [2] T. P. I. P. Ltd., Artificial intelligence system. 2015.
- [3] D. M. Atia and H. T. El-madany, "Analysis and design of greenhouse temperature control using adaptive neuro-fuzzy inference system," *Journal of Electrical Systems and Information Technology*, vol. 4, no. 1, pp. 34-48, 2017/05/01/ 2017, doi: <https://doi.org/10.1016/j.jesit.2016.10.014>.
- [4] S. Revathi, T. K. Radhakrishnan, and N. Sivakumaran, "Climate control in greenhouse using intelligent control algorithms," in 2017 American Control Conference (ACC), 24-26 May 2017 2017, pp. 887-892, doi: 10.23919/ACC.2017.7963065.
- [5] A. Esquivel-Salas, J. Castañeda-Delgado, M. Salas-Guzmán, and D. Arredondo-Salcedo, "Greenhouse temperature control based on Fuzzy Logic," *Journal of Computational Systems and ICTs*, pp. 1-8, 06/30 2021, doi: 10.35429/JCSI.2021.19.7.1.8.
- [6] G. Cevallos, M. Herrera, R. Jaimez, H. Aboukheir, and O. Camacho, "A practical hybrid control approach for a greenhouse microclimate: a hardware-in-the-Loop implementation," *Agriculture*, vol. 12, no. 11, p. 1916, 2022. [Online]. Available: <https://www.mdpi.com/2077-0472/12/11/1916>.
- [7] F. Mahmood, R. Govindan, A. Bermak, D. Yang, and T. Al-Ansari, "Data-driven robust model predictive control for greenhouse temperature control and energy utilisation assessment," *Applied Energy*, vol. 343, p. 121190, 2023/08/01/ 2023, doi: <https://doi.org/10.1016/j.apenergy.2023.121190>.
- [8] B. Scholkopf and A. J. Smola, *Learning with Kernels: Support Vector Machines, Regularization, Optimization, and Beyond*. MIT Press, 2001.
- [9] J. Berrendero, A. Cuevas, and J. Torrecilla, "The mRMR variable selection method: a comparative study for functional data," *Journal of Statistical Computation and Simulation*, vol. 86, pp. 1-17, 05/27 2015, doi: 10.1080/00949655.2015.1042378.